下载APP

# 17｜集成学习：机器学习模型如何“博采众长”?

2021-10-06 黄佳

《零基础实战机器学习》 课程介绍 >

**讲述：黄佳**

时长 23:13 大小 21.26M

你好，我是黄佳。恭喜你连闯 4 关，成功来到最后一关“裂变关”。

回忆一下这一路的旅程，在获客关中，我们给用户分组画像；在变现关中，我们关注用户的生命周期价值；在激活关中，我们预测了 App 的激活数字；在留存关中，我们分析了与用户流失相关的因素。

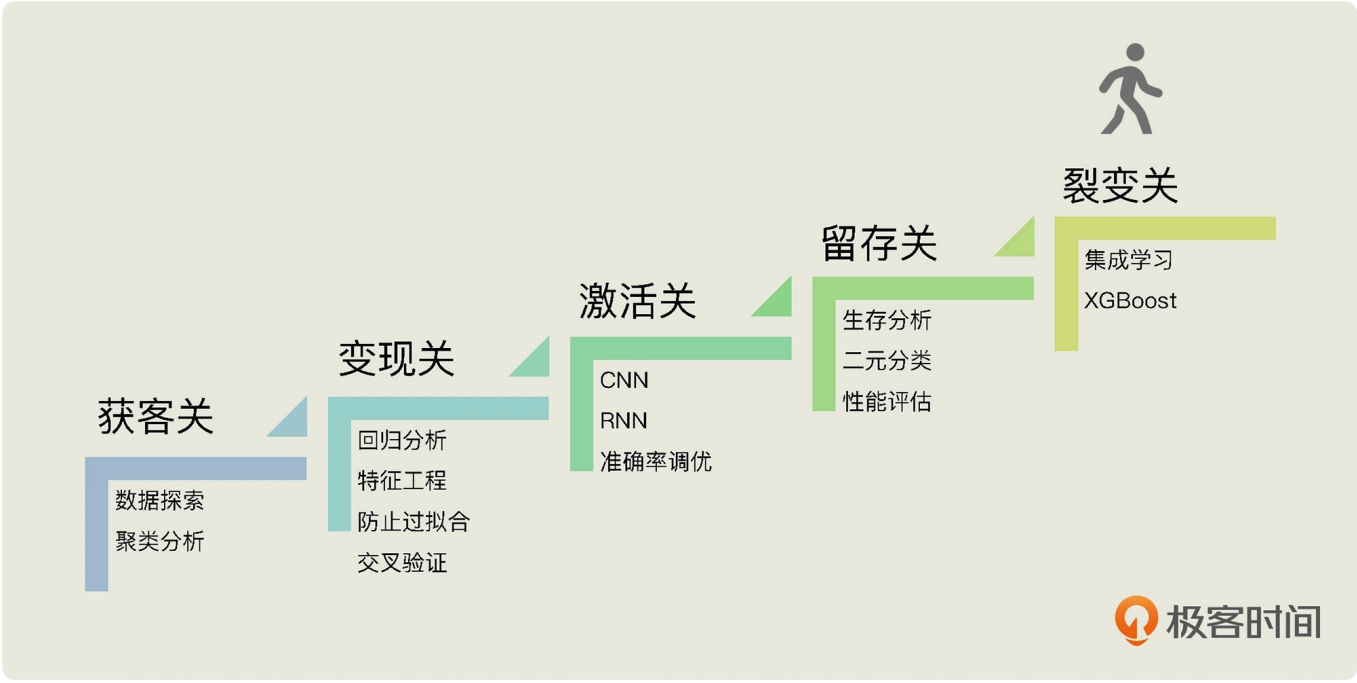


那么在裂变关中，我们将从数据中寻找蛛丝马迹，发现“易速鲜花”运营中最佳的“裂变方案”。不过，除了介绍运营中的裂变方案外，今天，我们还要好好讲一讲集成学习。

为什么要专门拿出一讲来谈集成学习呢？我们在第 9 讲说过，我们用机器学习建模的过程，就是和过拟合现象持续作斗争的过程。而集成学习在机器学习中是很特别的一类方法，能够处理回归和分类问题，而且它对于避免模型中的过拟合问题，具有天然的优势。那么，集成学习的优势是怎么形成的？学习了今天的课程后你就会找到答案。

## 定义问题

老规矩，我们先来定义今天要解决的问题。

说起裂变，你可能并不会感到陌生。裂变是让产品自循环、自传播的重要工具。像邀请新人得红包、分享 App 领优惠券、友情助力拿赠品、朋友圈打卡退学费等等，都是裂变的玩法。

最近，“易速鲜花”运营部门提出了两个裂变思路。方案一是选择一批热销商品，让老用户邀请朋友扫码下载 App 并成功注册，朋友越多，折扣越大。我们把这个方案命名为“疯狂打折”，它走的是友情牌。方案二是找到一个朋友一起购买，第二件商品就可以免费赠送，这叫“买一送一”。

提出两个裂变方案之后，运营部门收集了转化数据。那么，我们今天的目标就是**根据这个数据集，来判断一个特定用户在特定的裂变促销之下，是否会转化。**

| | A | B | C | D | E | F | G | H | I | J | K | L |
|---|---|---|---|---|---|---|---|---|---|---|---|---|
| 1 | 用户码 | 性别 | 年龄 | 城市 | 入会月数 | 会员类型 | 活跃用户 | 会员积分 | 总消费 | 年收入 | 裂变方案 | 是否转化 |
| 2 | 1 | 女 | 40 | 杭州 | 9 | 2 | 1 | 516 | 6360.66 | 0 | 疯狂打折 | 0 |
| 3 | 2 | 男 | 69 | 杭州 | 6 | 2 | 1 | 682 | 28605 | 0 | 疯狂打折 | 0 |
| 4 | 3 | 女 | 32 | 杭州 | 9 | 1 | 1 | 803 | 10378.09 | 236311.1 | 买一送一 | 1 |
| 5 | 4 | 女 | 37 | 苏州 | 0 | 2 | 1 | 778 | 25564.01 | 129909.8 | 买一送一 | 1 |
| 6 | 5 | 男 | 55 | 苏州 | 4 | 3 | 0 | 547 | 3235.61 | 136976.2 | 买一送一 | 1 |
| 7 | 6 | 男 | 36 | 杭州 | 5 | 2 | 0 | 541 | 23861.53 | 0 | 买一送一 | 0 |
| 8 | 7 | 女 | 42 | 苏州 | 1 | 1 | 0 | 651 | 8552.92 | 143475.5 | 买一送一 | 1 |

这个问题和我们之前预测用户是否会流失非常相似，也是一个二元分类问题。

下面我们就导入相关的包，并读入数据：

复制代码

```
import pandas as pd #导入Pandas
import numpy as np #导入NumPy
df_fission = pd.read_csv('易速鲜花裂变转化.csv') #载入数据
df_fission.head() #显示数据
```

输出如下：

| | 用户码 | 性别 | 年龄 | 城市 | 入会月数 | 会员类型 | 活跃用户 | 会员积分 | 总消费 | 年收入 | 裂变方案 | 是否转化 |
|---|---|---|---|---|---|---|---|---|---|---|---|---|
| **0** | 1 | 女 | 40 | 杭州 | 9 | 2 | 1 | 516 | 6360.66 | 0.0000 | 疯狂打折 | 0 |
| **1** | 2 | 男 | 69 | 杭州 | 6 | 2 | 1 | 682 | 28605.00 | 0.0000 | 疯狂打折 | 0 |
| **2** | 3 | 女 | 32 | 杭州 | 9 | 1 | 1 | 803 | 10378.09 | 236311.0932 | 买一送一 | 1 |
| **3** | 4 | 女 | 37 | 苏州 | 0 | 2 | 1 | 778 | 25564.01 | 129909.8079 | 买一送一 | 1 |
| **4** | 5 | 男 | 55 | 苏州 | 4 | 3 | 0 | 547 | 3235.61 | 136976.1948 | 买一送一 | 1 |
| **...** | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| **9995** | 9996 | 男 | 49 | 扬州 | 7 | 2 | 1 | 746 | 1930.44 | 0.0000 | 疯狂打折 | 0 |
| **9996** | 9997 | 男 | 36 | 杭州 | 1 | 1 | 0 | 569 | 29593.82 | 82517.8587 | 买一送一 | 0 |
| **9997** | 9998 | 女 | 55 | 扬州 | 7 | 1 | 0 | 850 | 32841.84 | 0.0000 | 疯狂打折 | 1 |
| **9998** | 9999 | 男 | 35 | 扬州 | 5 | 1 | 1 | 529 | 21564.34 | 117800.7531 | 买一送一 | 0 |
| **9999** | 10000 | 女 | 48 | 苏州 | 5 | 1 | 0 | 657 | 19371.82 | 176622.9201 | 疯狂打折 | 1 |

10000 rows × 12 columns

在这个数据集中，共有 10000 个数据样本，也就是 10000 个用户的信息。其他字段都很好理解，我们重点来看看“裂变方案”字段。这个字段表示的是该用户所导流到的裂变类型，一个用户看到的是“疯狂打折”优惠页，还是“买一送一”优惠页，是随机分配的结果。对于一个用户，二者只能属于其一。而与之对应的“是否转化”字段就**是我们用来预测转化率的标签了。**

下面我们进入数据可视化和预处理的环节。

## 数据可视化和预处理

在数据可视化部分，我只想看一看转化和未转化的比例，也就是购买产品和未购买产品的比例。看这个比例是为了看这个数据集中的各类别样本数是否平衡。

复制代码

```
import matplotlib.pyplot as plt #导入pyplot模块
import seaborn as sns #导入Seaborn
fig = sns.countplot('是否转化', data=df_fission) #创建柱状计数图
fig.set_ylabel("数目") #Y轴标题
plt.show() #显示图像
```

输入如下：

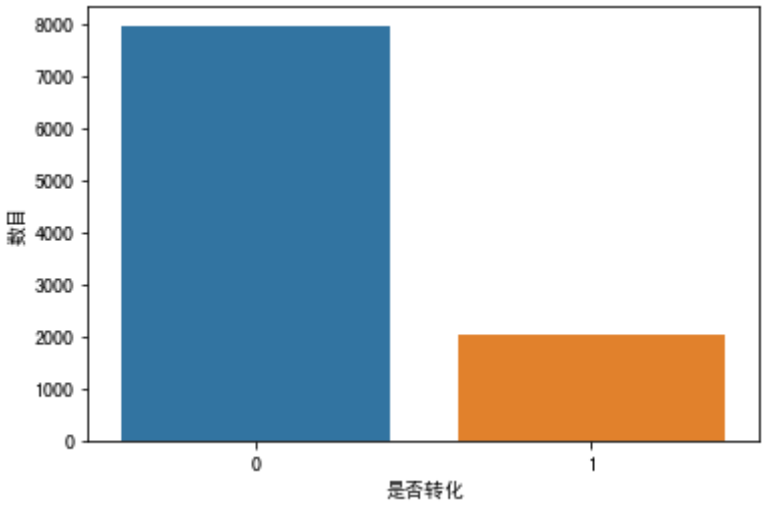


结果显示，在 10000 个用户中，大概有 2000 个用户购买了产品，转化率大概在 20%。说明运营人员给我们的是一个并不平衡的分类数据集。这个结论将为我们后续的算法选择做出指导。

下面，我们把数据集中的类别变量，转变为机器学习模型能够读取的虚拟变量（也叫哑编码或哑变量）：

复制代码

```
# 把二元类别文本数字化
df_fission['性别'].replace("女",0,inplace = True)
df_fission['性别'].replace("男",1,inplace=True)
# 显示数字类别
print("Gender unique values",df_fission['性别'].unique())
# 把多元类别转换成多个二元哑变量，然后贴回原始数据集
df_fission = pd.get_dummies(df_fission, drop_first = True)
df_fission # 显示数据集
```

输出如下：

| | 用户码 | 性别 | 年龄 | 入会月数 | 会员类型 | 活跃用户 | 会员积分 | 总消费 | 年收入 | 是否转化 | 城市_杭州 | 城市_苏州 | 裂变方案_疯狂打折 |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| **0** | 1 | 0 | 40 | 9 | 2 | 1 | 516 | 6360.66 | 0.0000 | 0 | 1 | 0 | 1 |
| **1** | 2 | 1 | 69 | 6 | 2 | 1 | 682 | 28605.00 | 0.0000 | 0 | 1 | 0 | 1 |
| **2** | 3 | 0 | 32 | 9 | 1 | 1 | 803 | 10378.09 | 236311.0932 | 1 | 1 | 0 | 0 |
| **3** | 4 | 0 | 37 | 0 | 2 | 1 | 778 | 25564.01 | 129909.8079 | 1 | 0 | 1 | 0 |
| **4** | 5 | 1 | 55 | 4 | 3 | 0 | 547 | 3235.61 | 136976.1948 | 1 | 0 | 1 | 0 |

然后，我们再来构建标签和特征数据集，并拆分出训练集和测试集，最后对特征进行归一化缩放。我们对这些步骤已经非常熟悉了，我就不需再过多解释了：

复制代码

```
X = df_fission.drop(['用户码','是否转化'], axis = 1) # 构建特征集
y = df_fission.是否转化.values # 构建标签集
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X,y,test_size = 0.2)
from sklearn.preprocessing import MinMaxScaler #导入归一化缩放器
scaler = MinMaxScaler() #创建归一化缩放器
X_train = scaler.fit_transform(X_train) #拟合并转换训练集数据
X_test = scaler.transform(X_test) #转换测试集数据
```

这样，数据集就准备好啦，现在，我们进入算法选择环节。

## 算法选择：集成学习

我们前面说，判断一个特定用户在特定的裂变促销之下是否会转化，属于二元分类问题。对于二分类问题，我们在第 15 讲中也提到过，它不仅可以用逻辑回归解决，还可以通过 SVM、集成学习、神经网络等多种模型完成。现在，我们就借助这一讲的项目，着重来了解一下集成学习方法的原理和应用。

**集成学习 (ensemble learning)，是通过构建出多个模型（这些模型可以是比较弱的模型），然后将它们组合起来完成任务的机器学习算法。**所以，它实际上并不是一种机器学习算法，而是一个机器学习算法的家族。通常情况下，集成学习将几个表现一般的模型集成在一起，就能大幅提升模型的性能，这就是集成学习的天然优势。

在这个算法家族中，很多算法都是“网红”算法，比如随机森林、梯度提升机（英文叫 GB 或 GBDT）和极限梯度提升（eXtreme Gradient Boosting，即 XGBoost，有时候简称 XGB）等，这些都是非常流行的机器学习算法，在很多许多领域都取得了成功，并且还是很多人赢得各种机器学习竞赛的主要方法。

那么，为什么几个表现一般的模型集成在一起，性能会大幅提升？下面，我们来探究一下。首先，请你回忆一下，我们在第 9 讲中讲过，机器学习在训练时有一个从欠拟合到过拟合的过程：

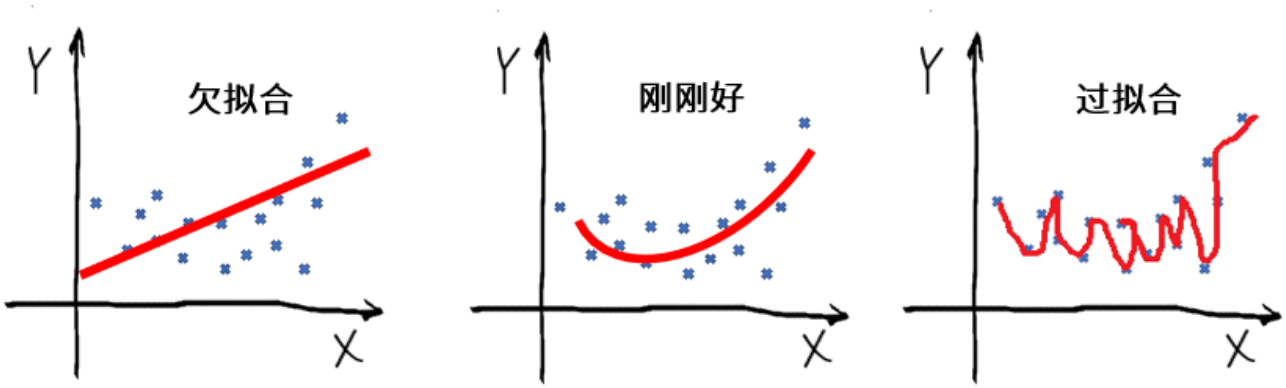


从欠拟合到过拟合

如果结合我们已经比较熟悉的损失曲线，就可以用下面这张图来描述这一过程：

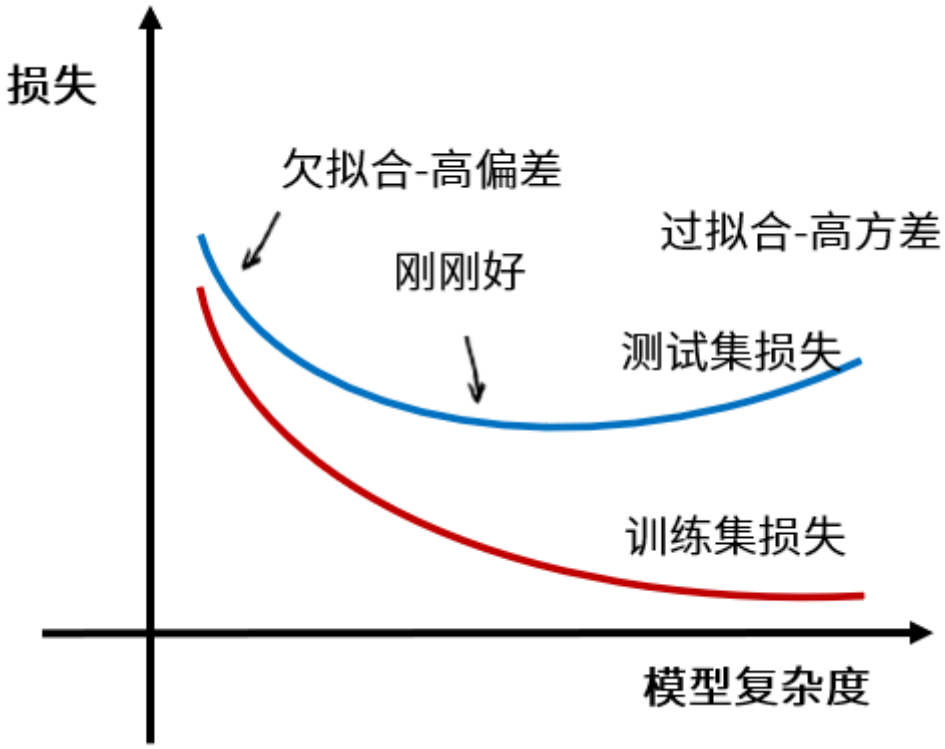


损失、偏差、方差与模型复杂度之间的关系

我们说，当给定一个学习任务，在训练初期，模型对训练集的拟合还未完善，训练集和测试集上面的损失也都比较大，这时候的模型处于欠拟合状态。由于模型的拟合能力还不强，数据集的改变是无法使模型的效率产生显著变化的，所以，如果我们把此时的模型应用于训练集和测试集的数据，都会出现“**高偏差**”。

随着训练次数增多，模型的拟合能力在调整优化的过程中会变得越来越强，训练集上和测试集上的损失也都会不断下降。

当充分训练之后，模型已经完全拟合了训练集数据，训练集上的损失也变得非常小。但是，这时候的模型很容易受数据的影响，数据的轻微扰动都会导致模型发生显著变化。这时候，如果我们把模型应用于不同的数据集（包括测试集），会出现**很高的方差**，也就是过拟合的状态。

总的来说就是，模型在欠拟合状态会出现“高偏差”，在过拟合状态会出现“高方差”，这都不符合我们的预期。只有在拟合刚刚好的时候，模型才是相对成功的。这时候，模型的偏差和方差处于平衡态，均不会太高。

你可能注意到，在上面的讲述中，我引入了“方差”和“偏差”这两个新概念。方差，是从统计学中引用过来的概念，它表示的是一组数据距离其均值的离散程度。而“偏差”是

机器学习里概念，用来衡量模型的准确程度。

在机器学习中，“低偏差”和“低方差”是我们希望达到的效果。可是，一般来说, 低偏差与低方差是鱼与熊掌不可兼得的，这被称作偏差 - 方差窘境 (bias-variance dilemma)。下面这张打靶图，就形象地说明了这一点：

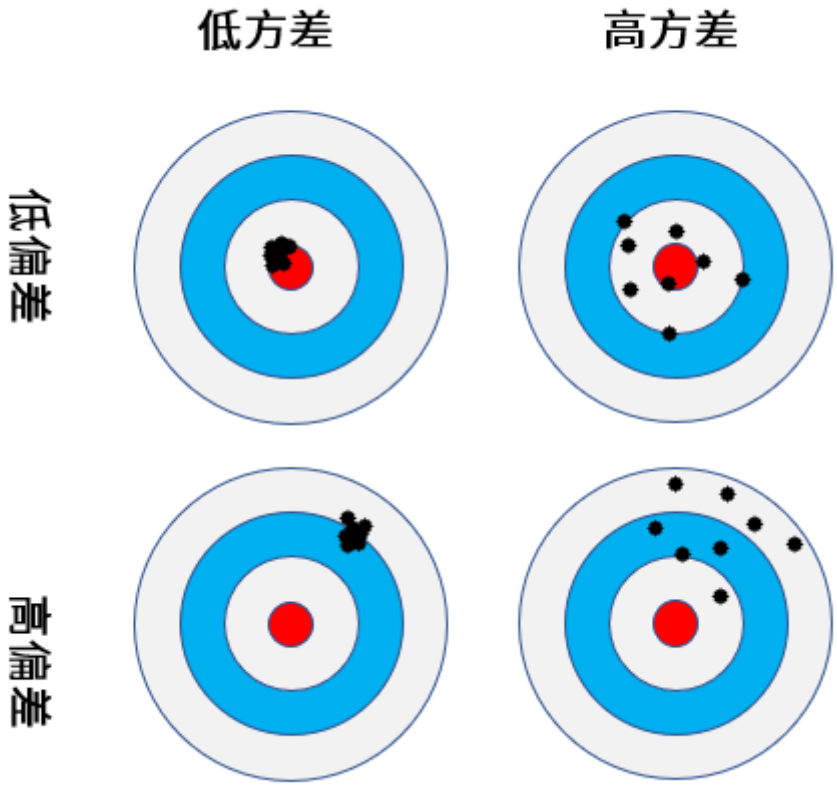


方差和偏差对预测结果所造成的影响

其实，机器学习性能优化领域的最核心问题，就是不断地在“欠拟合 - 过拟合”之间，也就是“偏差 - 方差”之间，探求最佳平衡点，换句话说，就是训练集优化和测试集泛化的平衡点。而机器学习的性能优化是有顺序的，我们一般是先减小偏差，再聚焦于降低方差。

那说了这么多，你也许有点不耐烦了：这些内容和集成学习到底有什么关系呢？

其实啊，集成学习的优点就在于，它可以通过组合一些比较简单的算法，来保留这些算法训练出的模型“方差低”的优势；在此基础之上，集成学习又能引入复杂的模型，来扩展简单算法的预测空间。所以，集成学习是同时减小方差和偏差的大招。

集成学习的核心思想是训练出多个模型并将这些模型进行组合。根据分类器的训练方式和组合预测的方法，集成学习中两种最重要的方法就是：降低偏差的 Boosting 和降低方差的 Bagging。

下面，我们就一边讲解这两种方法，一边用它们来解决“特定用户在特定的裂变促销之下是否会转化成功”的预测问题。

我们先来看 Boosting。

## 降低偏差：Boosting 方法

Boosting 方法是把梯度下降的思想应用在了机器学习算法的优化上，让弱模型对数据的拟合逐渐增强。它的基本思路就是：持续地通过新模型来优化同一个基模型（基模型，也就是 Boosting 开始时的初始模型），当一个新的弱模型加入进来的时候，Boosting 就在原有模型的基础上整合这个新模型，然后形成新的基模型。而对这个新的基模型的训练，则会一直聚集于之前模型的误差点（也就是原模型预测出错的样本）上，这样做的目标是不断减小模型的预测误差。

在 Boosting 方法中，有三种很受欢迎的算法，分别是 AdaBoost、GBDT 和 XGBoost。其中，AdaBoost 会对样本进行加权；GBDT 在 AdaBoost 的基础上，还会定义一个损失函数，通过梯度下降来优化模型；而 XGBoost 则在 GBDT 的基础上，进一步优化了梯度下降的方式。

这三种算法都可以用来解决我们这一讲的分类问题（其实也可以用于回归问题）。下面，我们来逐一做个讲解。

### 1. AdaBoost 算法

我们先来使用 AdaBoost 算法。在处理分类问题时，AdaBoost 会先给不同的样本分配不同的权重，被分错的样本的权重在 Boosting 过程中会增大，新模型会因此更加关注这些被分错的样本；反之，被分正确的样本的权重会减小。接着，AdaBoost 会将修改过权重的新数据集输入到新模型进行训练，产生新的基模型。最后，AdaBoost 会把每次得到的基模型组合起来，并根据其分类错误率对模型赋予权重，集成为最终的模型。

下面，我们用 AdaBoost 算法来预测一下用户在特定的裂变促销之下是否会转化，并给出评估分数：

复制代码

```
from sklearn.ensemble import AdaBoostClassifier # 导入AdaBoost 模型
dt = DecisionTreeClassifier() # 选择决策树分类器作为AdaBoost 的基准算法
ada = AdaBoostClassifier(dt) # AdaBoost 模型
ada.fit(X_train, y_train) # 拟合模型
y_pred = ada.predict(X_test) # 进行预测
print("AdaBoost 测试准确率: {:.2f}%".format(ada.score(X_test, y_test)*100))
print("AdaBoost 测试F1分数: {:.2f}%".format(f1_score(y_test, y_pred)*100))
```

输出如下：

复制代码

```
AdaBoost 测试准确率: 78.75%
AdaBoost 测试F1分数: 50.18%
```

结果显示，AdaBoost 算法测试准确率是 78.75%，F1 分数为 50.18%。这个 F1 分数并不是很理想，我们需要考虑一下有没有更优的算法。而下面要介绍的 GBDT 算法就对 AdaBoost 算法做出了进一步的改进。

## 2. GBDT 算法

GBDT 算法也叫梯度提升（Granding Boosting）算法，它是梯度下降和 Boosting 方法结合的产物。因为常见的梯度提升都是基于决策树模型（机器学习中就把决策树模型简称为树）的，所以我们这里会把它称作是 GBDT，即梯度提升决策树（Granding Boosting Decision Tree）。

我们知道，前面的 AdaBoost 算法只是对样本进行加权，但 GBDT 算法与之不同，它还会定义一个损失函数，并对损失和机器学习模型所形成的函数进行求导，每次生成的模型都是沿着前面模型的负梯度方向（一阶导数）进行优化，直到发现全局最优解。也就是说，在 GBDT 的每一次迭代中，当前的树所学习的内容是之前所有树的结论和损失，在学习中，GBDT 会拟合得到一棵新的树，而这棵新的树就相当于是之前每一棵树的效果累加。

下面，我们用 GBDT 算法来预测用户是否转化，并给出评估分数：

复制代码

```
from sklearn.ensemble import GradientBoostingClassifier # 导入梯度提升模型
gb = GradientBoostingClassifier() # 梯度提升模型
gb.fit(X_train, y_train) # 拟合模型
y_pred = gb.predict(X_test) # 进行预测
print(" 梯度提升测试准确率: {:.2f}%".format(gb.score(X_test, y_test)*100))
print(" 梯度提升测试F1分数: {:.2f}%".format(f1_score(y_test, y_pred)*100))
```

输出如下：

复制代码

```
梯度提升测试准确率: 87.00%
梯度提升测试F1 分数: 61.19%
```

结果显示，GBDT 算法的测试准确率是 87.00%，F1 分数为 61.19%。F1 分数果然大幅提升，看来 GBDT 算法还不错。其实，还有比 GBDT 更厉害的集成学习算法，它就是算法 XGBoost 算法。

## 3. XGBoost 算法

XGBoost 算法也叫极端梯度提升（eXtreme Gradient Boosting），有时候也直接叫作 XGB。它和 GBDT 类似，也会定义一个损失函数。不过，不同的是，GBDT 只用到一阶导数信息，而 XGBoost 会利用泰勒展开式把损失函数展开到二阶后求导。由于利用了二阶导数信息，XGBoost 在训练集上的收敛会更快。

在使用 XGBoost 之前，我们需要通过 pip 语句安装 XGBoost 包，当然，你也可以在 Anaconda 的 Environments（环境）界面中，直接搜索并安装 XGBoost 包：

复制代码

```
pip install xgboost
```

下面，我们用 XGBoost 算法来预测用户是否转化，并给出评估分数：

复制代码

```
from xgboost import XGBClassifier # 导入XGB 模型
xgb = XGBClassifier() # XGB 模型
```

```
xgb.fit(X_train, y_train) # 拟合模型
y_pred = xgb.predict(X_test) # 进行预测
print("XGB 测试准确率: {:.2f}%".format(xgb.score(X_test, y_test)*100))
print("XGB 测试F1分数: {:.2f}%".format(f1_score(y_test, y_pred)*100))
```

输出如下：

复制代码

```
XGB 测试准确率: 87.00%
XGB 测试F1分数: 63.17%
```

结果显示，XGBoost 算法的测试准确率是 87.00%，F1 分数为 63.17%。

可以看出，在上述三种算法中，XGBoost 算法的性能是最佳的。虽然它的预测准确率和 GBDT 相同，但是它的 F1 分数高，而 F1 分数是我们更重视的指标。

下面，我们再来介绍并使用能降低方差的 Bagging 方法。

## 降低方差：Bagging 方法

Bagging 是 Bootstrap Aggregating 的缩写，有人把它翻译为套袋法、装袋法，或者自助聚合，到现在，还没有一个统一的叫法。所以，我们就直接用它的英文名称 Bagging。

Bagging 算法的基本思想是从原始的数据集中抽取数据，形成 K 个随机的新训练集，然后训练出 K 个不同的模型。

具体来讲，Bagging 算法首先会在原始样本集中随机抽取 K 轮，每轮抽取 n 个训练样本作为一个训练集。这时候，有些样本可能被多次抽取，而有些样本可能一次都没有被抽取，这叫做有放回的抽取）。在抽取 K 轮之后，就会形成 K 个训练集，注意，这 K 个训练集是彼此独立的。这个过程也叫作 bootstrap（可译为“自举”或“自助采样”）。

接着，Bagging 算法会每次使用一个训练集，并通过相同的机器学习算法（如决策树、神经网络等）得到一个模型。因为有 K 个训练集，所以一共可以得到 K 个模型。我们把这些模型称为“基模型”（base estimator）或者“基学习器”。

最后，对于这 K 个模型，Bagging 算法会用不同的方式得到基模型的集成结果：如果是分类问题，Bagging 算法会对 K 个模型投票，进而得到分类结果；如果是回归问题，Bagging 算法会计算 K 个模型的均值，将其作为最后的结果。

因为随机抽取数据的方法能减少可能的数据干扰，所以经过 Bagging 的模型将会具有“低方差”” 。一般来说，Bagging 有三种常见的算法：决策树的 Bagging、随机森林算法和极端随机森林。

## 1. 决策树的 Bagging

多数情况下的 Bagging，都是基于决策树的。构造随机森林的第一步，其实就是对多棵决策树进行 Bagging，我们把它称为树的聚合（ Bagging of Tree ）。

决策树这种模型，具有显著的低偏差、高方差的特点。也就是说，决策树模型受数据的影响特别大，一不小心，训练集准确率就接近 100% 了，而这种效果又不能移植到其他的数据集上，所以，这是很明显的过拟合现象。集成学习的 Bagging 算法就是从决策树模型开始，着手解决它太过于精准，又不易泛化的问题。当然，Bagging 的原理并不仅限于决策树，它还可以扩展到其他机器学习算法。

下面，我们用决策树的 Bagging 算法来预测用户是否转化，并给出评估分数：

复制代码

```
from sklearn.ensemble import BaggingClassifier # 导入Bagging 分类器
from sklearn.tree import DecisionTreeClassifier # 导入决策树分类器
from sklearn.metrics import (f1_score, confusion_matrix) # 导入评估指标
dt = BaggingClassifier(DecisionTreeClassifier()) # 只使用一棵决策树
dt.fit(X_train, y_train) # 拟合模型
y_pred = dt.predict(X_test) # 进行预测
print(" 决策树测试准确率: {:.2f}%".format(dt.score(X_test, y_test)*100))
print(" 决策树测试F1 分数: {:.2f}%".format(f1_score(y_test, y_pred)*100))
bdt = BaggingClassifier(DecisionTreeClassifier()) # 树的Bagging
bdt.fit(X_train, y_train) # 拟合模型
y_pred = bdt.predict(X_test) # 进行预测
print(" 决策树Bagging 测试准确率: {:.2f}%".format(bdt.score(X_test, y_test)*100))
print(" 决策树Bagging 测试F1分数: {:.2f}%".format(f1_score(y_test, y_pred)*100))
```

输出如下：

```
决策树测试准确率: 85.10%
决策树测试F1分数: 58.17%
决策树Bagging 测试准确率: 85.55%
决策树Bagging 测试F1 分数: 58.66%
```

复制代码

结果显示，对于这个数据集来说，决策树 Bagging 的测试集 F1 分数有提升，但是优势不明显。不过没关系，我们可以试一下更常见的随机森林算法，它其实是经过改进的“决策树 Bagging 算法”。

## 2. 随机森林算法

当我们说到集成学习，最关键的一点是：各个基模型的相关度要小，差异性要大。模型间差异越大（也就是异质性越强），集成的效果越好。两个准确率为 99% 的模型，如果其预测结果都一致，也就没有提高的余地了。因此，对决策树做集成，关键就在于各棵树的差异性是否够大。

为了实现基模型差异化的目标，随机森林在树分叉时，增加了对特征选择的随机性，而并不总是考量全部的特征。这个小小的改进，就进一步提高了各棵树的差异。

下面，我们用随机森林算法来预测用户是否转化，并给出评估分数：

复制代码

```
from sklearn.model_selectifrom sklearn.ensemble import RandomForestClassifier
rf = RandomForestClassifier() # 随机森林模型
rf.fit(X_train, y_train) # 拟合模型
y_pred = rf.predict(X_test) # 进行预测
print(" 随机森林测试准确率: {:.2f}%".format(rf.score(X_test, y_test)*100))
print(" 随机森林测试F1分数: {:.2f}%".format(f1_score(y_test, y_pred)*100))
```

输出如下：

复制代码

```
 随机森林测试准确率: 87.20%
 随机森林测试F1分数: 61.79%
```

可以看到，随机森林测试 F1 分数很明显地高于决策树模型和决策树的 Bagging。

## 3. 极端随机森林算法

最后，我们再来看极端随机森林算法。极端森林算法在随机森林的基础上，又增加了进一步的随机性。

随机森林算法在树分叉时会随机选取 m 个特征作为考量，对于每一次分叉，它还会遍历所有的分支，然后选择基于这些特征的最优分支。这在本质上仍属于贪心算法（greedy algorithm），即在每一步选择中都采取在当前状态下最优的选择。而极端随机森林算法则不同，它一点也不“贪心”，它甚至不回去考量所有的分支，而是随机选择一些分支，从中拿到一个最优解。

下面，我们用极端随机森林算法来预测用户是否转化，并给出评估分数：

复制代码

```
from sklearn.ensemble import ExtraTreesClassifier # 导入极端随机森林模型
ext = ExtraTreesClassifier() # 极端随机森林模型
ext.fit(X_train, y_train) # 拟合模型
y_pred = ext.predict(X_test) # 进行预测
print(" 极端随机森林测试准确率: {:.2f}%".format(ext.score(X_test, y_test)*100))
print(" 极端随机森林测试F1分数: {:.2f}%".format(f1_score(y_test, y_pred)*100))
```

输出如下：

复制代码

```
 极端随机森林测试准确率: 87.05%
 极端随机森林测试F1分数: 60.58%
```

结果显示，对于“预测一个特定用户在特定的裂变促销下是否会转化”这个问题来说，极端随机森林测试 F1 分数，要高于决策树和树的 Bagging，但是低于随机森林算法。

最后，我们可以把上述各个集成学习算法的得分，都显示在一张图中，来比较一下它们在这个问题上的优劣。

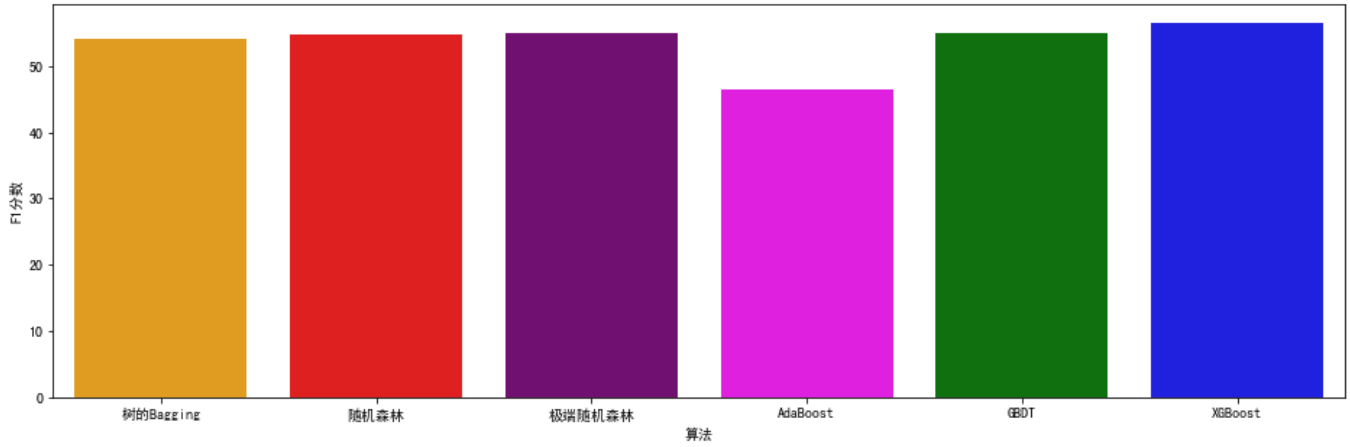


图中可以看出，对于这个问题，XGBoost、随机森林和极端随机森林，都是比较好的选择。

## 总结一下

好，到这里，我们关于集成学习的介绍就结束了，我们来做个总结。

集成学习模型是将多种同质或者异质的模型集成组合在一起，来形成更优的模型。而在这个过程的目标就是，减少机器学习模型的方差和偏差，找到机器学习模型在欠拟合和过拟合之间的最佳平衡点。

那么，怎么降低偏差呢？我们可以用 Boosting 方法，把梯度下降的思想应用在机器学习算法的优化上，使弱模型对数据的拟合逐渐增强。Boosting 也常应用于决策树算法上，其中的 GBDT 和 XGBoost 算法都非常受欢迎。

那怎么降低方差呢？这就要借助 Bagging 方法了。Bagging 方法通常基于决策树，在随机生成数据集上训练出各种各样不同的树。其中的随机森林算法是在树分叉时，增加了对特征选择的随机性。随机森林在很多问题上都是一个很强的算法。我们可以把它作为一个基准，如果找到了比随机森林还优秀的模型，你就可以很欣慰了。

那么最后，如果让我在集成学习家族的算法里，给你推荐两种常用且效果好的算法，基于我个人的经验，我会觉得 XGBoost、GBDT 和随机森林是优于其它几种的。

## 思考题

好，在这一讲的最后，我给你留 3 个思考题：

1. 我在使用这些集成学习算法时，都只使用了默认参数，请你用 GridSearchCV 进行参数的网格搜索，找出针对这个问题更优的参数，训练出更好的模型；
2. 请你绘出上述各个算法的混淆矩阵；
3. 请你使用深度神经网络解决这个问题，看看是深层网络的性能好，还是集成学习的性能好？

欢迎你在留言区和我分享你的观点，如果你认为这节课的内容有收获，也欢迎把它分享给你的朋友，我们下一讲再见！

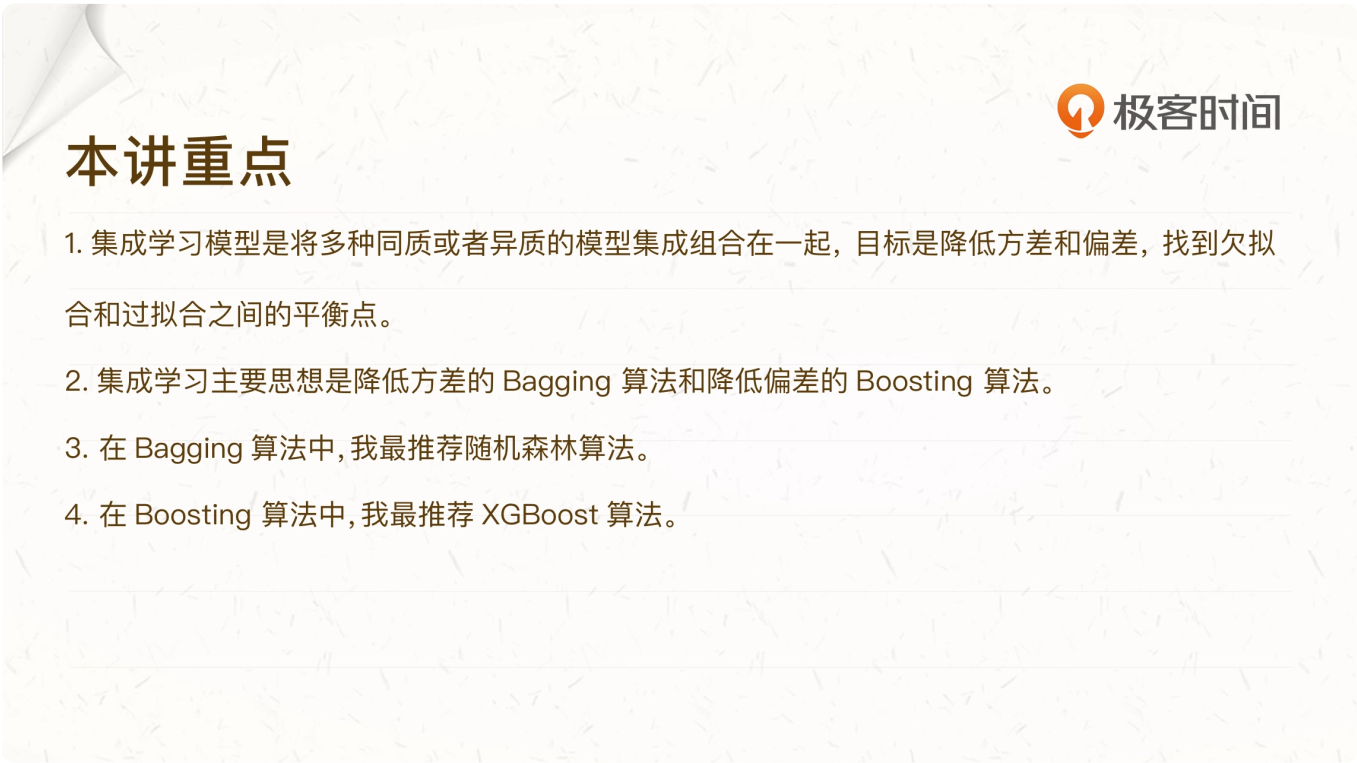


分享给需要的人，Ta订阅后你可得 20 元现金奖励

生成海报并分享

赞 0 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 16 | 性能评估：不平衡数据集应该使用何种评估指标？

## 精选留言 (1)

写留言

**谦**

2021-10-06

之前对集成算法对参数不是很理解，在learning_rate和n_estimators对选择上有过经验教训，惯性思维认为learning_rate只是决定训练的速度，然后就随便选了一个learning_rate对Adaboost，XGBoost，GBDT 和随机森林分别进行训练，得到对结果Adaboost > 随机森林 > GBDT > XGBoost。因为网上都说XGB很厉害，这个的结果看上去不太合理，这时候通过增加n_estimators对数量，XGB的结果终于排到第一名，后面发现如果不增减n_esti...

展开

作者回复: 这是宝贵的调参过程之细节，感谢分享！！

1